

APLICAÇÃO DE ALGORITMOS DE INTELIGÊNCIA ARTIFICIAL EM SISTEMAS DE RECOMENDAÇÃO

APPLICATION OF ARTIFICIAL INTELLIGENCE ALGORITHMS IN RECOMMENDATION SYSTEMS

Leandro Batista Dias¹, Guilherme de Moraes²

¹Fundação Educacional de Fernandópolis, leandrodias@fef.edu.br

²Fundação Educacional de Fernandópolis, guilherme@fef.edu.br

Área: Informação e Comunicação
Subárea: Matemática e Inteligência Computacional

RESUMO

Como uma ferramenta altamente eficaz para orientar os usuários em direção a conteúdos semelhantes aos já consumidos, os Sistemas de Recomendações (SRs) são extremamente relevantes, pois, aumentam significativamente a precisão ao sugerir o que o cliente deseja. O objetivo geral desse artigo é investigar a aplicação de algoritmos de Inteligência Artificial (IA) em sistemas de recomendação, com foco em serviços de *streaming*. Para o alcance do objetivo traçado foi desenvolvida uma pesquisa em duas etapas. A primeira etapa foi uma pesquisa bibliográfica e a segunda uma pesquisa prática de desenvolvimento de um algoritmo para recomendação de filmes e séries para usuários de uma plataforma de *streaming*. Com base nesses resultados, se considerou que o algoritmo de filtragem colaborativa com base em itens apresenta uma melhor eficiência geral, com menor tempo de execução e maior estabilidade, sendo ideal para plataformas que precisam lidar com elevado número de usuários e itens. Por outro lado, a filtragem colaborativa com base em usuários, apesar de eficaz em certos contextos, apresenta uma eficiência menor quando aplicada a grandes volumes de dados. Concluiu-se que este trabalho teve como objetivo investigar a aplicação de algoritmos de IA em sistemas de recomendação, com ênfase em serviços de streaming. Foi possível concluir que esses sistemas de recomendação são fundamentais para aprimorar a experiência dos usuários, fornecendo sugestões personalizadas, que atendem suas preferências. Tanto a filtragem colaborativa baseada em usuários quanto a baseada em itens se mostraram eficazes na fidelização de clientes, pois oferecem conteúdo alinhado aos interesses dos usuários.

Palavras-chave: *Streaming* 1. Inteligência Artificial 2. Sistema de Recomendação 3.

ABSTRACT

As a highly effective tool for guiding users towards content similar to that already consumed, Recommendation Systems (RS) are extremely relevant, as they significantly increase accuracy by suggesting what the customer wants. The general aim of this article is to investigate the application of Artificial Intelligence (AI) algorithms in recommendation systems, with a focus on streaming services. In order to achieve this objective, a two-stage study was carried out. The first stage was a bibliographic survey and the second a practical survey to develop an algorithm for recommending movies and series to users of a streaming platform. Based on these results, it was considered that the collaborative filtering algorithm based on items has a better overall efficiency, with less execution time and greater stability, making it ideal for platforms that have to deal with a high number of users and items. On the other hand, user-based collaborative filtering, although effective in certain contexts, is less efficient when applied to

large volumes of data. In conclusion, the aim of this work was to investigate the application of AI algorithms in recommendation systems, with an emphasis on streaming services. It was possible to conclude that these recommendation systems are fundamental to improving the user experience by providing personalized suggestions that meet their preferences. Both user-based and item-based collaborative filtering proved to be effective in building customer loyalty, as they offer content aligned with users' interests.

Keywords: Streaming 1. Artificial Intelligence 2. Recommendation System 3.

1 INTRODUÇÃO

O crescente aumento de serviços de *streaming* com seu catálogo de conteúdos gigantesco, gera dificuldades na escolha do que consumir. Isso deixa os usuários à deriva nesse mundo imersivo. Contudo, se o cliente não consegue efetuar sua escolha em instantes há um risco real do cancelamento do serviço oferecido. Assim, para facilitar tal processo, empresas de *streaming* buscam implantar sistemas de recomendações (KISCHINHEVSKY *et al.*, 2015).

Tendo em vista a fidelização de novos clientes e a retenção de usuários já aderentes aos serviços de *streaming*, empresas de grande porte como a Spotify, que oferece uma plataforma de *streaming* de músicas e *podcasts*, e a Netflix cuja sua principal fonte de renda deriva de assinantes, os quais procuram assistir filmes, séries e documentários, observam o sistema de recomendação como um mecanismo essencial para seus negócios (RAMOS; OLIVEIRA, 2022).

De acordo com a fonte fornecida *Music Consumer Insight Report 2018*, mostra o avanço do crescimento de serviços de *streaming* no Brasil. Segundo o relatório, citado por Solitto (2018), o mercado brasileiro consome uma quantidade de *streamings* de vídeos maior comparado a outros países, ficando atrás apenas da Rússia e do México (JEKINS, 2014). Deixando de forma clara o público-alvo e sua preferência.

Como uma ferramenta altamente eficaz para orientar os usuários em direção a conteúdos semelhantes aos já consumidos, os Sistemas de Recomendações (SRs) são extremamente relevantes, pois, aumentam significativamente a precisão ao sugerir o que o cliente deseja (PINTO *et al.*, 2021).

Os SRs mostram serem ferramentas essenciais, que facilitam a interação com os usuários. Tendo um exemplo claro, na Netflix clientes consomem 80% dos títulos por meio desse recurso, em contrapartida, apenas 20% dos usuários optam por utilizar a barra de pesquisa para buscar os conteúdos desejados. Isso também se deve ao fato de que a própria interface da Netflix facilita a visualização desses conteúdos, a serem indicados (GOMEZ-URIBE; HUNT, 2015).

Em se tratando de ciências computacional os SRs são algoritmos que classificam e recomendam produtos, e os conteúdos. Ele opera por meio de dados coletados dos usuários que usufruem desse mesmo sistema, desse modo é analisado o comportamento prático do cliente dentro da plataforma que está implementada o SR. Indicando assim produtos ou conteúdos semelhantes aos já adquiridos (KARAKAYALI *et al.*, 2018).

O objetivo principal deste trabalho é investigar a aplicação de algoritmos de Inteligência Artificial (IA) em sistemas de recomendação, com foco em serviços de *streaming*. Será explorado como esses algoritmos contribuem para melhorar a experiência do usuário, aumentando a precisão das recomendações e, conseqüentemente, a satisfação e retenção dos clientes. A pesquisa abordará diferentes tipos de algoritmos, destacando as suas vantagens e limitações no contexto de plataforma como a Netflix.

Este artigo está organizado da seguinte forma: a sessão 1 é a introdução do estudo; a seção 2 apresenta o referencial teórico, discutindo os conceitos fundamentais de *streaming*, inteligência artificial e filtragem colaborativa. A seção 3 detalha a metodologia utilizada na

pesquisa, explicando os métodos e técnicas empregados para a coleta e análise dos dados. Na seção 4, são apresentados e discutidos os resultados obtidos, seguido pelas considerações finais na seção 5, em que são destacadas as principais conclusões e sugestões para trabalhos futuros.

2 REFERENCIAL TEÓRICO

A presente seção objetiva a apresentação de conceitos básicos para o esclarecimento acerca do trabalho e metodologia propostos, com base em dados secundários, ou seja, em informações sobre a IA em sistemas de recomendação, demonstrando a relevância do uso da tecnologia nas empresas, de forma a conhecer seus clientes e fidelizá-los, com base no oferecimento de um serviço de recomendação.

2.1 STREAMING: CONCEITO E EVOLUÇÃO

Devido ao crescimento de conteúdos disponibilizados em plataformas de *streamings*, corporações de mídias tradicionais, como a televisão e rádio aderiram a essa nova estratégia passando seus conteúdos de forma online nas plataformas, modificando o fluxo televisivo habitual (MUNGIOLI *et al.*, 2018).

Nesse sentido, cabe esclarecer que:

A RealNetworks foi pioneira nos mercados de streaming de mídia e transmitiu um dos primeiros eventos de áudio pela Internet: um jogo de beisebol entre o New York Yankees e o *Seattle Mariners*, em 5 de setembro de 1995. Em 1997, a empresa lançou o *RealVideo*, anunciando a tão aguardada tecnologia de streaming de vídeo. Acredita-se que, nos anos 2000, mais de 85% do conteúdo de streaming na Internet estava no formato Real (ASSIM, 2024, p. 1).

Utilizando sites e aplicativos por meio de operadoras, as plataformas de *streaming* oferecem conteúdos pagos ou gratuitos. Tais aplicativos são projetados para serem suportados em diferentes dispositivos, como computadores, *notebooks*, *smart TVs*, *smartphones* e *tablets*. Dessa forma, para o bom funcionamento do serviço oferecido é necessário apenas uma boa conexão com a internet (OLIVEIRA *et al.*, 2023).

Ao longo dos anos, a forma de interação entre as emissoras de radiodifusão e os usuários foi transformada pelo uso da internet. Segundo Guerrero Pérez (2018), isso se deve ao avanço tecnológico. Novos canais digitais e diferentes meios de acesso proporcionaram uma maneira de consumir conteúdos distintos do tradicional. Observa-se que o maior acesso a essas plataformas está vinculado ao público mais jovem (GALLARDO-CAMACHO *et al.*, 2016).

A plataforma de *streaming*, como a Netflix, tende a revolucionar como o usuário consome vídeos, séries e documentários (próprios ou de terceiros), todos devidamente licenciados, o que gera segurança em relação aos direitos autorais. Tais vídeos, uma vez produzidos, são direcionados para uma equipe especializada que atribui gênero, tipo de conteúdo e dramaturgia. Essas pessoas são chamadas de *'taggers'* e, esse processo facilita que o material seja corretamente agrupado no sistema de recomendação (LOBATO, 2016).

A indústria midiática vem sofrendo alterações por meio do *streaming* e da utilização da internet para fins de consumo desses conteúdos digitais (SMITH; TELANG, 2016; BURROUGHS, 2014). De acordo com os dados extraídos do *Music Consumer Insight Report 2018*, pesquisa elaborada pela International Federation of the Phonographic Industry (IFPI), que coletou informações sobre os vinte maiores mercados de música do mundo, cerca de 86% dos consumidores entre 16-64 anos acessam músicas e vídeos por meio de serviços de *streaming*. A pesquisa realizada no Brasil mostra que 77% dos usuários brasileiros utilizam plataformas de *streaming* para reproduzir seus conteúdos (MONTARDO; VALIATI, 2021).

No meio de uma revolução, a indústria audiovisual passou de um paradigma de distribuição para um de consumo, com as principais decisões sendo tomadas pelos consumidores. No contexto do *streaming*, uma vez que o conteúdo é digitalizado, controlar seu impacto torna-se extremamente complexo, visto que a logística e a distribuição desse material frequentemente estão nas mãos dos usuários (PASQUÍN, 2017).

Mudanças podem ser notada nessa era em relação a plataformas de *streamings* igual a Netflix e Spotify. Essas mudanças trouxeram benefícios claros, como a democratização do acesso e a conveniência, mas, também, apresenta desafios, como questões de privacidade de dados e a criação de bolhas de filtragem devido aos algoritmos de recomendação. Pesquisas futuras devem investigar como equilibrar a personalização com a diversidade de conteúdo, garantindo acesso a uma ampla gama de perspectivas, maximizando os benefícios do *streaming* e mitigando seus desafios (NEIRA *et al.*, 2021; GUTIÉRREZ LOZANO; CUARTERO, 2020; PASQUÍN, 2017).

2.2 INTELIGÊNCIA ARTIFICIAL: CONCEITO E APLICAÇÃO

Nessa nova era, em que a IA ganha espaço no mercado e, de certo modo, impulsiona avanços tecnológicos, as IAs realizam trabalhos racionais e afazeres que por vezes podem ser considerados complexos se realizados por humanos. Esse raciocínio empregado no desenvolvimento dessas tarefas está ligado ao que se considera inteligência (LUDERMIR, 2021).

A maioria das áreas produtivas enfrentarão impactos diretos ou indiretos devido à IA, com variações conforme o país. As mudanças já são visíveis em setores como a produção industrial, turismo e alimentação, planejamento urbano, arquitetura e mobilidade, serviços de saúde e educação (MCKINSEY GLOBAL INSTITUTE, 2017).

Presentes no dia a dia contemporâneo as IAs assumiram um papel importante ao auxiliarem os seres humanos em tarefas cotidianas, como ouvir música no *Spotify*, assistir vídeos na Netflix, realizar compras na Amazon, ou até mesmo, integrar-se ao *Global Positioning System* (GPS). Essas tarefas, que antes eram realizadas por humanos, hoje são executadas por algoritmos (NAVARRO, 2018).

A IA se destaca pelo aumento da automação de diferentes tarefas. Atividades como dirigir carros, entregar produtos, classificar itens e prever tendências podem ser processadas com minuciosidade. Dessa forma, as companhias podem manter um serviço de excelência em setores diversificados (SANTODIGITAL, 2022).

O MYCIN foi um sistema pioneiro na aplicação de IA na medicina, criado por Edward *Shortliffe* como parte de sua tese de doutorado. Desenvolvido na linguagem *Lisp*, o sistema atuava como uma espécie de ajudante especializado em antibioticoterapia, direcionado a médicos, paramédicos e estudantes de medicina. Destacou-se por ser o primeiro a resolver problemas de diferentes graus de complexidade (GUARIZI; OLIVEIRA, 2014).

Na atualidade, as IAs já causam impactos significativos, como, por exemplo, o ChatGPT, essa ferramenta gera textos com uma boa escrita, o que pode ser utilizado para agilizar o desenvolvimento de escritas científicas. Além disso, o sistema pode analisar com precisão um amplo volume de dados, identificar padrões e tendências, dentre outras funções. Com base nisso, já se projeta um cenário futurístico em que os cientistas poderão utilizar os melhores recursos dessas ferramentas (ROSSONI, 2022).

No momento as IAs já estão causando impactos em diversas áreas, desde a automação de tarefas cotidianas até importantes avanços na medicina e na ciência. O desenvolvimento contínuo dessas tecnologias gera a expectativa de que possam transformar ainda mais a sociedade, oferecendo novas oportunidades e desafios. De qualquer forma, a IA tem demonstrado versatilidade ao auxiliar na gestão de quase todas as atividades humanas, como:

educação, saúde, finanças, lazer, tarefas domésticas e até no desempenho de algumas profissões liberais, em que predominam a técnica, conhecimento intelectual, criatividade e a experiência (ARBELÁEZ-CAMPILLO *et al.*, 2021).

2.3 FILTRAGEM COLABORATIVA: CONCEITO E FUNCIONAMENTO

Na contemporaneidade, devido ao desenvolvimento das IAs, existem inúmeros sistemas de recomendação, como o da Amazon (que recomenda produtos), *Spotify* (que recomenda músicas) e Netflix (que recomenda filmes). Esses sistemas são estruturados com base nas preferências dos usuários, tornando as recomendações mais precisas e assertivas (LUDERMIR, 2021).

Por ser uma técnica amplamente utilizada, a filtragem colaborativa permite fornecer recomendações personalizadas aos clientes em diversas áreas, como produtos, filmes e músicas. A estrutura desse algoritmo calcula a similaridade das avaliações entre os usuários, aprimorando a precisão das recomendações (FAREED, 2023).

A filtragem colaborativa utiliza simultaneamente a semelhança entre os usuários e seus itens para fornecer recomendações. Isso permite que produtos adquiridos por um usuário B com gostos semelhantes ao usuário A sejam recomendados a este último. Esse processo ocorre por meio de uma análise inteligente realizada pelo algoritmo (GOOGLE DEVELOPERS, 2023).

Os sistemas de recomendação baseados em filtragem colaborativa têm desempenhado um papel significativo na ascensão de serviços web e plataformas de conteúdo como Amazon, Netflix e YouTube nos últimos anos. No contexto atual de amplitude do volume de informações, antecipar o que o cliente deseja antes mesmo que ele saiba é uma vantagem. Esses algoritmos de recomendação são usados para oferecer conteúdo ou produtos relevantes ao consumidor, com base em seus gostos ou escolhas anteriores (TURING, 2023).

A filtragem colaborativa enfrenta desafios como o *cold-start*, quando novos usuários ou itens entram no sistema sem histórico suficiente, prejudicando a precisão das recomendações. Para contornar isso, são adotadas estratégias mistas, integrando informações como idade do usuário, relações de interação e tags de produtos (DHRUV *et al.*, 2020). Além disso, a esparsidade dos dados, resultante da falta de avaliações suficientes na matriz de usuários e itens, pode comprometer a qualidade das recomendações, exigindo que os sistemas considerem a quantidade de dados disponíveis (NATH, 2023).

Assim, tem-se que todo algoritmo de filtragem colaborativa trabalha com traços de personalidade dos usuários, agrupando-os com base em suas preferências. Ao aplicar essa estrutura corretamente, é possível observar uma melhora na qualidade e precisão das recomendações com base em vizinhança, em que as preferências do usuário A podem ser semelhantes às do usuário B, considerando a aplicação dessa estratégia (AGUIAR *et al.*, 2020).

Os sistemas de recomendação fundamentados em filtragem colaborativa são essenciais para o sucesso de diversas plataformas online. Esses sistemas analisam os comportamentos e preferências dos usuários para oferecer recomendações personalizadas, aumentando a satisfação e o envolvimento dos usuários. Mesmo enfrentando desafios como a falta de dados e o problema do *cold-start*, as inovações em modelos híbridos e técnicas de aprendizado profundo têm aprimorado a precisão e a eficiência dessas recomendações (TURING, 2023).

2.4 SISTEMA DE RECOMENDAÇÃO COM USO DE ALGORITMOS DE IA

A usabilidade do sistema de recomendação integrado à IA em plataformas de *streaming*, como a Netflix, Spotify; além claro plataformas de e-commerces, oferece sugestões de conteúdos personalizados de acordo com a preferência do usuário, promovendo uma imersão maior. Com sugestões aparecendo na barra de tarefas e na tela inicial, a escolha do usuário é

facilitada. Isso ocorre por meio de uma série de estratégias, incluindo a análise de preferências coletivas de outros perfis, utilizando algoritmos inteligentes para sugerir títulos relevantes ao usuário (NETFLIX, 2019; GOMEZ-URIBE; HUNT, 2015).

Utilizando a técnica de filtragem colaborativa, pode-se recomendar conteúdo com maior precisão. Essa técnica consiste em analisar um ou mais indivíduos e seus interesses em comum, podendo então recomendar itens automaticamente para outro usuário, por meio de escolhas realizadas pelos mesmos. Para a execução desse processo, é necessária uma base de dados contendo informações relevantes sobre os perfis e suas escolhas (CAMPOS, 2017).

A construção de matrizes de dados é fundamental em sistemas de recomendação, pois permite representar as interações entre usuários e itens de forma estruturada. Essas matrizes, conhecidas como matrizes usuário-item, são geralmente esparsas devido à quantidade limitada de interações registradas. Para lidar com essa esparsidade e melhorar a precisão das recomendações, técnicas como a fatoração de matrizes são empregadas, decompondo a matriz original em fatores latentes que capturam padrões subjacentes nas preferências dos usuários. Essa abordagem facilita a previsão de interações não observadas, aprimorando a qualidade das recomendações fornecidas pelo sistema (ZHANG, 2019).

Em sistemas de recomendação, os itens geralmente são descritos por atributos categóricos, como diretor, ator, gênero e país de origem, no caso de filmes. No entanto, existem poucas métricas adequadas para calcular a similaridade entre itens baseados nesses atributos. Um exemplo é o algoritmo desenvolvido por Nguyen et al., que utiliza a métrica de similaridade simples para medir a proximidade entre dois itens, considerando suas características categóricas e representando-as formalmente em cálculos matemáticos (YU; WANG; GAO, 2014).

Nos últimos anos, diversas inovações tecnológicas têm sido introduzidas para aprimorar os sistemas de recomendação. O uso de métricas como a similaridade de cosseno permite a identificação de padrões complexos nos dados dos usuários, proporcionando sugestões mais precisas. Para a execução desse processo, o sistema constrói matrizes de itens e usuários a partir das avaliações coletadas, possibilitando a recomendação de itens relevantes. (ALURA, 2024).

Um dos desafios mais significativos enfrentados pelos sistemas de recomendação é o problema do *cold-start*. Esse problema ocorre quando novos usuários ou itens entram no sistema sem um histórico suficiente de interações, dificultando a geração de recomendações precisas. Para mitigar esse problema, são adotadas diversas estratégias, como a integração de dados demográficos dos usuários, informações contextuais e *feedback* explícito. Além disso, a esparsidade dos dados, resultante da falta de avaliações suficientes na matriz de usuários e itens, pode comprometer a qualidade das recomendações, exigindo abordagens que considerem a quantidade limitada de dados disponíveis (THINGSOLVER, 2023; ANALYTICS INDIA MAG, 2023). Embora o problema de *cold-start* seja amplamente reconhecido como um desafio em sistemas de recomendação, neste trabalho, sua ocorrência foi contornada devido ao pré-preenchimento dos dados na matriz de interações, eliminando valores nulos. Essa abordagem garantiu que todos os usuários e itens possuíssem informações suficientes para gerar recomendações, reduzindo o impacto da falta de histórico.

Coletar dados de forma inteligente com estratégias eficazes é essencial para enfrentar a problemática do *cold-start*. Isso permite promover adaptações no algoritmo, assegurando a precisão e relevância das recomendações geradas, mesmo com constantes mudanças nos cenários e dados de entrada. A adoção dessas práticas é crucial para a adaptação a novos contextos e para fornecer recomendações mais precisas (SYBHE, 2023).

Os objetivos deste trabalho foram alcançados com êxito, proporcionando uma base teórica robusta sobre sistemas de recomendação. A coleta eficiente de dados, a implementação de estratégias de aprendizado e a adaptação contínua são fundamentais para enfrentar desafios como o *cold-start*. Essas práticas asseguram a precisão e a relevância das recomendações, mesmo diante de constantes mudanças nos dados de entrada. Portanto, a adoção dessas práticas

é vital para a eficácia dos sistemas de recomendação em diversos contextos (COLLI; SILVEIRA, 2023).

3 METODOLOGIA

O caminho metodológico para o desenvolvimento desse artigo foi, em uma primeira fase, a pesquisa bibliográfica, ou seja, pesquisa em dados secundários. Segundo Marconi e Lakatos (2017) a pesquisa em dados secundários é a base de todo e qualquer estudo científico, visto que possibilita ao pesquisador fortalecer seu conhecimento sobre o tema central e adjacentes trabalhados.

A segunda fase foi realizada a partir da estrutura do desenvolvimento prático do sistema de recomendação. O algoritmo foi desenvolvido com base nos conhecimentos adquiridos pelo pesquisador em cursos on-line, como o curso “Inteligência artificial: sistemas de recomendação em Python”, ministrado por Jones Granatyr (2024) na plataforma Udemy, e o curso “*Recommender systems and deep learning in Python*”, oferecido pela Lazy Programmer Inc. (2024). Esses cursos forneceram uma base sólida para a implementação do sistema, abordando desde os fundamentos dos sistemas de recomendação até a execução do algoritmo.

Para a implementação, utilizou-se a linguagem de programação Python e um conjunto de bibliotecas amplamente utilizadas no contexto de análise de dados e aprendizado de máquina. A biblioteca Pandas foi essencial para a manipulação e análise dos dados, permitindo organizar as informações de uma forma estruturada, facilitando o processamento dos dados dos usuários e suas avaliações. A biblioteca NumPy foi utilizada para lidar com operações matemáticas e criação de matrizes, fundamentais para o cálculo das similaridades. Então a biblioteca Scikit-learn foi empregado para implementar os algoritmos de filtragem colaborativa, tanto fundamentada em usuários quanto em itens. Por fim na geração de gráficos para uma melhor visualização dos resultados foi utilizada a biblioteca Matplotlib.

A fórmula principal para a execução do algoritmo foi a Similaridade de Cosseno, conforme descrito por Credited Tecnologia (2024). Entretanto, para análises exploratórias de distâncias entre usuários, foi utilizada a métrica de Distância Euclidiana em algumas visualizações específicas, sem impacto nos resultados finais do sistema de recomendação.

Dado que a métrica de similaridade de cosseno é a principal utilizada no cálculo das recomendações, sua fórmula é apresentada a seguir:

$$\text{similarity}(\vec{A}, \vec{B}) = \cos(\vec{A}, \vec{B}) = \frac{\vec{A} \cdot \vec{B}}{\|\vec{A}\| * \|\vec{B}\|}$$

Na fórmula acima, \vec{A} e \vec{B} representam os vetores de avaliações dos usuários ou itens, enquanto o numerador $\vec{A} \cdot \vec{B}$ é o produto escalar entre os vetores. O denominador $\|\vec{A}\| \cdot \|\vec{B}\|$ realiza a normalização pela magnitude dos vetores, garantindo que a similaridade seja medida de forma relativa, variando entre -1 e 1."

O algoritmo principal utilizado no sistema de recomendação é a Similaridade de Cosseno, implementado com o auxílio da ferramenta cosine_similarity da biblioteca scikit-learn. Esse algoritmo mede a proximidade entre dois vetores ao calcular o cosseno do ângulo entre eles, sendo amplamente utilizado em sistemas de recomendação devido à sua eficiência em lidar com dados esparsos.

A Similaridade de Cosseno foi aplicada em dois contextos principais no sistema:

Filtragem colaborativa baseada em usuários (user-based): Neste contexto, o algoritmo compara os vetores de avaliações do usuário atual com os de outros usuários na base de dados, identificando aqueles com maior similaridade para recomendar itens avaliados positivamente por esses perfis semelhantes.

Filtragem colaborativa baseada em itens (item-based): Aqui, o algoritmo avalia os itens já avaliados pelo usuário e os compara com os demais disponíveis na base, recomendando aqueles que apresentam maior similaridade com os preferidos pelo usuário.

A escolha do algoritmo de Similaridade de Cosseno como base para o sistema deve-se à sua capacidade de capturar padrões de comportamento, ignorando diferenças de magnitude entre os vetores, o que o torna ideal para cenários de recomendação personalizados.

Um dos elementos fundamentais para a filtragem colaborativa implementada neste trabalho foi o uso da fórmula da similaridade de cosseno, que desempenhou um papel essencial na medição da similaridade entre usuários e itens. A similaridade de cosseno calcula o cosseno do ângulo entre dois vetores, representando as preferências dos usuários em relação aos itens disponíveis. Essa métrica permite identificar padrões de comportamento ao avaliar a orientação dos vetores, em vez da distância absoluta entre eles. Dessa forma, tornou-se uma ferramenta eficaz para sugerir conteúdos que se alinham mais de perto com as preferências individuais dos usuários, especialmente em cenários com dados esparsos.

Os testes do algoritmo foram realizados em um conjunto de dados fictícios de uma base de dados chamada *MovieLens*, inspirados nos exemplos dos cursos mencionados, simulando as avaliações de usuários sobre filmes e séries.

A base de dados *MovieLens* foi escolhida por apresentar interações suficientes entre usuários e itens. Essa estrutura pré-preenchida garantiu que o problema de cold-start, caracterizado pela ausência de informações iniciais, fosse minimizado. Dessa forma, o algoritmo pôde gerar recomendações relevantes sem necessidade de estratégias adicionais para tratar dados ausentes ou históricos insuficientes. As métricas de avaliação utilizadas incluíram a precisão e a taxa de recomendação adequadas, que permitiram avaliar a efetividade do sistema de recomendação desenvolvido e ajustar parâmetros para melhorar a qualidade das recomendações.

Os resultados da parte prática realizada foram apresentados em forma de gráficos, constituindo as figuras de 1 a 4, de forma a compreender como funciona um sistema de recomendação de serviços de *streaming* e como os usuários podem receber recomendações em relação aos filmes que gostam de assistir, tendo como base o filme *Star Wars*, que foi um clássico do cinema no ano de 1977.

4 ANÁLISE E DISCUSSÃO DOS RESULTADOS

Devido ao forte crescimento do volume de material disponibilizado em serviços de *streaming*, usuários enfrentam dificuldades para localizar o conteúdo desejado. Esse problema pode levar ao descontentamento dos clientes, resultando, em alguns casos, no cancelamento da assinatura do serviço. Tal situação pode acarretar impactos negativos nas finanças da empresa, prejudicando seu lucro e comprometendo o desenvolvimento corporativo.

Para solucionar esse problema, uma alternativa é o desenvolvimento e implementação de um sistema de recomendação baseado em algoritmos de IA. O objetivo deste trabalho é explorar como esses algoritmos podem ser utilizados para sugerir conteúdos relevantes aos usuários, de acordo com suas preferências e avaliações anteriores, melhorando a experiência do usuário e aumentando sua satisfação.

No sistema de recomendação desenvolvido são utilizadas ferramentas de IA que, por meio de cálculos de similaridade, como a similaridade de cosseno e o uso de matrizes de avaliação, buscam oferecer recomendações mais precisas. Além disso, a distância euclidiana

foi usada em análises exploratórias para medir distâncias absolutas entre vetores de avaliações, com foco em compreender padrões gerais entre usuários. Dessa forma, o sistema visa tornar o serviço de *streaming* mais atraente aos olhos dos clientes, sugerindo conteúdos que estejam alinhados aos seus interesses e, conseqüentemente, promovendo maior retenção dos assinantes.

Devido à sua capacidade de oferecer sugestões personalizadas para cada usuário, a filtragem colaborativa é amplamente aplicada em sistemas de recomendação. Segundo Ludemir (2021), esse método é utilizado em diversas plataformas, como plataformas de streaming e e-commerces. Suas recomendações são estruturadas a partir do comportamento e avaliações dos usuários, tornando assim as sugestões mais precisas e relevantes.

Com base na similaridade de avaliações entre os usuários, conforme descrito por Fareed (2023), a filtragem colaborativa utiliza métricas como a similaridade de cosseno para identificar proximidade entre perfis. Isso permite que filmes, séries, músicas e produtos sejam recomendados a partir de uma análise do gosto e da preferência dos clientes semelhantes. Na teoria, o usuário “A” tem um gosto similar ao usuário “B”. Assim, itens que foram avaliados positivamente pelo usuário “B” podem ser recomendados ao usuário “A”.

No contexto deste trabalho, a filtragem colaborativa foi implementada tanto para identificar usuários similares quanto para recomendar itens relacionados com base nas avaliações prévias dos usuários. Para medir a similaridade entre usuários e itens, utilizou-se exclusivamente a similaridade de cosseno, que calcula o cosseno do ângulo entre os vetores de avaliação. Essa métrica permitiu identificar padrões de comportamento e itens que compartilham características similares, otimizando as recomendações fornecidas.

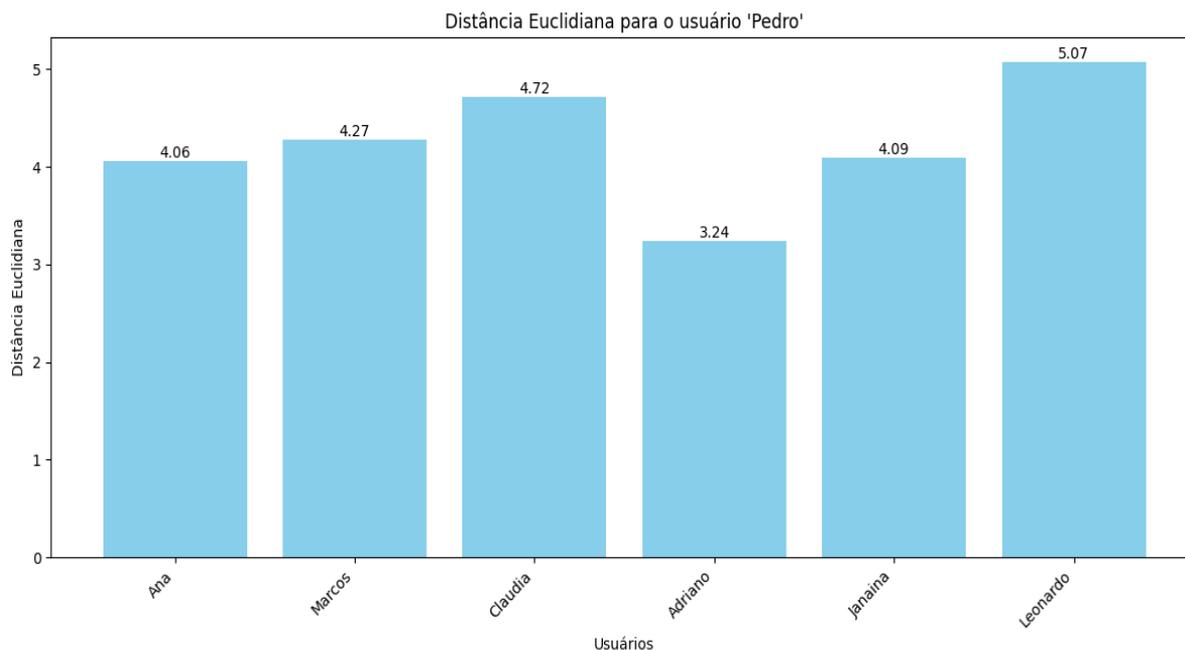
Como mencionado pelos Google Developers (2023), a filtragem colaborativa utiliza as similaridades entre usuários e itens para fornecer recomendações personalizadas. No sistema desenvolvido, os algoritmos de filtragem colaborativa foram responsáveis por gerar listas de recomendações tanto a partir das interações dos usuários quanto pela análise dos itens, de forma a melhorar a experiência de cada usuário, personalizando as sugestões com base em seus gostos e interesses anteriores.

O demonstrativo da Figura 1 traz de forma representativa a similaridade entre usuários, com base nas avaliações feitas pelos usuários em diferentes filmes da plataforma de *streaming*. A similaridade de cosseno foi utilizada para calcular a similaridade, em que menores valores indicam perfis mais próximos.

A Figura 1 ilustra a similaridade entre diferentes usuários do sistema de recomendação, com base nas avaliações fornecidas para os conteúdos disponíveis. Essa similaridade foi calculada usando a similaridade de cosseno, que mede o ângulo entre os vetores que representam as preferências dos usuários. Observa-se que os usuários mais similares possuem maior similaridade de cosseno (próximo de 1), indicando preferências semelhantes. Essa análise é essencial para a filtragem colaborativa, pois ajuda o sistema a identificar usuários cujas preferências são próximas e, assim, gerar recomendações mais precisas e personalizadas.

De acordo com o que foi discutido no referencial teórico, segundo Fareed (2023), a filtragem colaborativa com base em similaridade de usuários é uma das técnicas mais eficazes para sugerir conteúdos que sejam relevantes para os usuários. Na Figura 1 é possível observar que o usuário Pedro, por exemplo, tem uma alta similaridade com outros dois usuários, o que sugere que suas preferências podem ser usadas para recomendar novos conteúdos de maneira eficaz.

Figura 1 – Similaridade calculada entre usuários com base na Similaridade de Cosseno, destacando perfis semelhantes para gerar recomendações personalizadas.



Fonte: Elaborada pelo autor (2024).

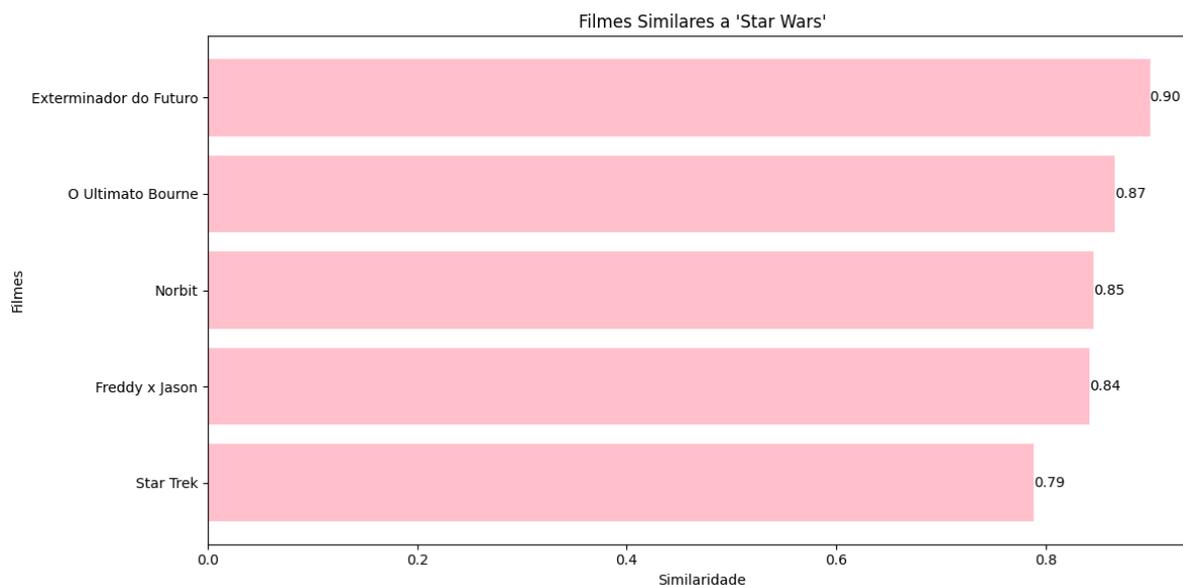
A Figura 2 traz em seu demonstrativo a similaridade entre filmes, com base nas avaliações fornecidas por diferentes usuários. Os valores de similaridade são calculados para identificar quais filmes compartilham características semelhantes e, assim, melhorar a recomendação de conteúdo.

Nesse sentido, a Figura 2 apresenta a similaridade entre diferentes filmes do catálogo, tendo como referência o filme Star Wars de 1977 considerado, na época, um clássico do cinema. A análise utilizou métricas de similaridade com base nas avaliações dos usuários, e o valor de similaridade varia entre 0 e 1, onde 1 indica similaridade máxima. Quanto mais próximo de 1 for o valor, maior a semelhança entre os filmes, indicando que esses títulos compartilham características que os tornam atrativos para públicos semelhantes.

Na Figura 2, se observa que o filme com maior similaridade em relação a Star Wars de 1977 é o Exterminador do Futuro, com um valor de 0,90, seguido por O Ultimato Bourne com 0,87 e Norbit com 0,85. Esses valores altos de similaridade indicam que esses filmes possuem características comuns, como gênero, ação e narrativa, tornando-os boas sugestões para os usuários que apreciam Star Wars.

Como mencionado por Fareed (2023), a filtragem colaborativa é uma técnica eficaz para melhorar a precisão das recomendações ao analisar a similaridade entre as avaliações dos usuários. No contexto deste trabalho, a filtragem colaborativa com base em itens permite que filmes com características similares sejam recomendados aos usuários, promovendo uma experiência personalizada que tende a aumentar a satisfação e retenção dos clientes.

Figura 2 – Similaridade entre filmes (filtragem colaborativa com base em usuários)



Fonte: Elaborada pelo autor (2024).

A Figura 3 apresenta a similaridade entre diferentes filmes do catálogo, tendo como referência o filme Star Wars de 1977. Esta análise utiliza a técnica de filtragem colaborativa com base em itens, que visa identificar filmes semelhantes de acordo com as avaliações dos usuários para um item específico. Os valores de similaridade variam entre 0 e 1, onde 1 indica similaridade máxima. Quanto mais próximo de 1, maior a probabilidade de os filmes compartilharem características que os tornam atrativos para o mesmo público-alvo.

Na Figura 3 tem-se que Return of the Jedi de 1983 possui uma alta similaridade em relação a Star Wars de 1977, com um valor de 0,88, seguido por Raiders of the Lost Ark do ano de 1981 com 0,76, e The Empire Strikes Back de 1980 com 0,75. Os valores apresentados indicam, que esses filmes compartilham características importantes, como o gênero de ficção científica e ação, a temática espacial e, até mesmo, semelhanças no estilo narrativo e atores, o que faz com que sejam boas sugestões para os fãs de Star Wars.

A filtragem colaborativa pode ser utilizada de duas maneiras principais, que é com base em usuários e em itens. A filtragem colaborativa, que se fundamenta em usuários foca em identificar usuários, os quais tenham perfis de avaliação similares. Na Figura 1, se observaram as similaridades entre diferentes usuários, o que ajuda a recomendar conteúdos, que foram bem avaliados por pessoas com gostos semelhantes.

Já a filtragem colaborativa com base em itens, como ilustrada na Figura 3, identifica quais itens são semelhantes entre si, considerando as avaliações que receberam dos usuários. Assim, se um usuário gostou de um determinado filme (neste caso, Star Wars), o sistema recomenda outros filmes que têm características similares. Segundo Fareed (2023), a filtragem colaborativa com base em itens é particularmente eficaz para garantir, que as recomendações estejam alinhadas com as características específicas do conteúdo já apreciado pelo usuário.

Quando se considera o uso da filtragem colaborativa é importante destacar, que cada abordagem se adapta melhor aos diferentes volumes de dados. A filtragem colaborativa com base em usuários geralmente funciona bem em conjuntos de dados menores, em que a análise de preferências pode ser feita diretamente entre os usuários. Esse tipo de filtragem se beneficia quando a quantidade de usuários ativos não é grande, facilitando a comparação direta entre perfis. No entanto, à medida que a quantidade de dados cresce, a complexidade e os custos computacionais aumentam significativamente.

Por outro lado, a filtragem colaborativa que se fundamenta em itens se mostra mais adequada para conjuntos de dados maiores e mais densos. Como ela se concentra nas características dos itens em vez dos usuários, o sistema consegue gerar recomendações mais consistentes, mesmo quando há um número elevado de itens e usuários. Isso faz com que a abordagem com base em itens seja mais escalável e eficiente para volumes de dados mais robustos.

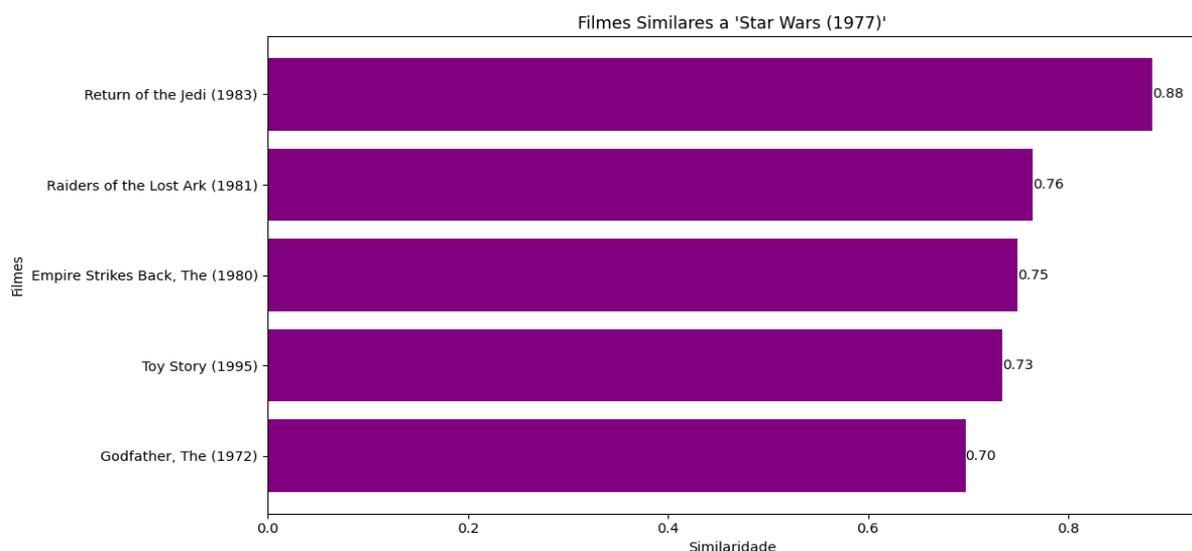
Na implementação de sistemas de recomendação, diversas bibliotecas de Python são amplamente utilizadas para lidar com os cálculos de similaridade e processamento de dados. Para a filtragem colaborativa com base em usuários, bibliotecas como *Scikit-learn* e *NumPy* são bastante populares. *Scikit-learn* oferece ferramentas para calcular a similaridade entre vetores, como a similaridade cosseno, enquanto *NumPy* é usada para operações matemáticas eficientes, como manipulação de *Arrays* e cálculos de distância.

Já na filtragem colaborativa com base em itens, uma das bibliotecas mais importantes é a *Pandas*. *Pandas* desempenha um papel fundamental ao permitir a manipulação e análise de conjuntos de dados de forma organizada e eficiente, facilitando a criação de *Data Frames* que ajudam a agrupar e processar avaliações dos itens. Comparada a outras bibliotecas, a *Pandas* oferece uma estrutura tabular útil para a análise dos dados dos itens, possibilitando que as avaliações sejam acessadas e processadas de maneira intuitiva. Isso faz com que a filtragem colaborativa com base em itens, que envolve um contingente operações de agregação e análise de grupos de itens, seja beneficiada pela flexibilidade e facilidade de manipulação de dados que a *Pandas* proporciona.

Nesse sentido, ao aplicar a filtragem colaborativa com base em itens, a *Pandas* permite agrupar avaliações por título de filmes e calcular médias, desvios e outras métricas estatísticas de forma eficiente, o que contribui para um modelo mais refinado e uma recomendação mais assertiva. Esse diferencial é particularmente importante quando se trabalha com catálogos de filmes, onde há uma grande quantidade de avaliações para processar.

O uso de bibliotecas como *Scikit-learn*, *NumPy* e *Pandas* contribui significativamente para a eficiência dos sistemas de recomendação. A abordagem com base em itens, especialmente, a *Pandas*, oferece uma maneira mais robusta e escalável de gerar recomendações, o que se torna essencial em um cenário onde há diversos itens e volume de avaliações.

Figura 3 – Similaridade entre filmes (filtragem colaborativa com base em itens)



Fonte: Elaborada pelo autor (2024).

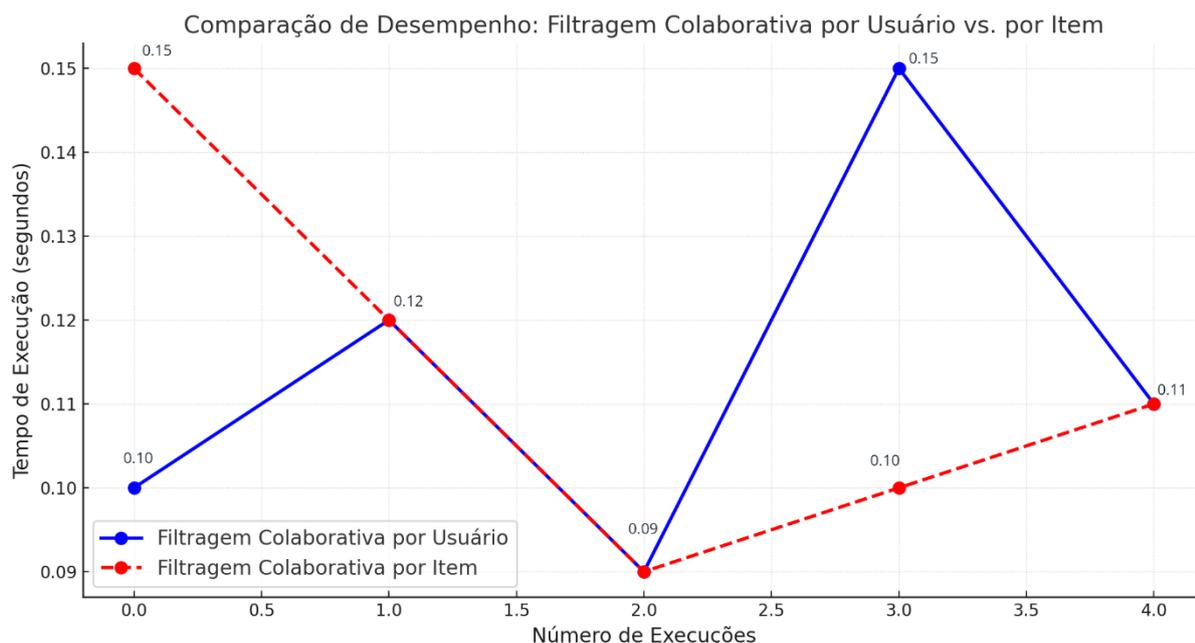
A Figura 4 apresenta a comparação de desempenho entre dois algoritmos de filtragem colaborativa: o algoritmo com base em usuários e em itens. A linha azul representa o desempenho da filtragem colaborativa com base em usuários, enquanto a linha vermelha tracejada indica o desempenho da filtragem colaborativa com base em itens. O eixo horizontal indica o número de execuções realizadas, e o eixo vertical exibe o tempo de execução em segundos. O objetivo dessa análise é avaliar qual dos algoritmos apresentam melhor desempenho em termos de tempo de processamento e estabilidade ao longo de diferentes execuções.

Pondera-se que a Figura 4 mostra que, o desempenho do algoritmo de filtragem colaborativa com base em usuários apresenta uma variabilidade significativa ao longo das execuções. É possível observar flutuações marcantes, incluindo um pico na segunda execução, com um valor de 0,15 segundos, que representa o maior tempo de execução. Essa variabilidade se deve ao fato de que, na filtragem colaborativa com base em usuários, é necessário comparar o perfil de um usuário com outros, o que se torna computacionalmente custoso, especialmente, quando o número de usuários é elevado. Como resultado, o desempenho deste algoritmo pode se tornar menos previsível e menos eficiente conforme o volume de dados aumenta.

Por outro lado, o algoritmo de filtragem colaborativa com base em itens demonstrou um desempenho mais estável e eficiente. Ao longo das execuções, os tempos de processamento foram menores e apresentaram menos variação, indicando que o cálculo das similaridades entre os itens é menos impactado pelo número de usuários. Esse comportamento torna o algoritmo com base em itens mais adequado para contextos com grandes volumes de dados, proporcionando uma maior escalabilidade e eficiência.

Com base nesses resultados, se considerou que o algoritmo de filtragem colaborativa com base em itens apresenta uma melhor eficiência geral, com menor tempo de execução e maior estabilidade, sendo ideal para plataformas que precisam lidar com elevado número de usuários e itens. Por outro lado, a filtragem colaborativa com base em usuários, apesar de eficaz em certos contextos, apresenta uma eficiência menor quando aplicada a grandes volumes de dados.

Figura 4 – Comparação de desempenho com base em usuários e item



Fonte: Elaborada pelo autor (2024).

5 CONSIDERAÇÕES FINAIS

Este trabalho teve como objetivo investigar a aplicação de algoritmos de IA em sistemas de recomendação, com ênfase em serviços de *streaming*. Foi possível concluir que esses sistemas de recomendação são fundamentais para aprimorar a experiência dos usuários, fornecendo sugestões personalizadas, que atendem suas preferências. Tanto a filtragem colaborativa baseada em usuários quanto a baseada em itens se mostraram eficazes na fidelização de clientes, pois oferecem conteúdo alinhado aos interesses dos usuários.

Quanto aos objetivos específicos, foi explorada a eficácia da filtragem colaborativa com base em usuários. Verificou-se que, embora essa abordagem seja adequada para conjuntos de dados menores, sua escalabilidade apresenta limitações diante de volumes mais amplos de informações. Por outro lado, a filtragem com base em itens demonstrou maior eficiência em contextos, que envolvem um grande número de usuários e itens, garantindo mais estabilidade e consistência nos resultados.

Concluiu-se que, enquanto a filtragem com base em usuários é mais adaptável em situações com interações limitadas, a filtragem com base em itens se destaca no tratamento de dados em maior escala. Para análises complementares e ilustrativas, a distância euclidiana foi utilizada em gráfico específico, com o intuito de facilitar a interpretação de dados pelos usuários do sistema. Essa diferença permite que os sistemas de recomendação ajustem suas estratégias de forma a otimizar a qualidade das sugestões, garantindo, assim, uma experiência mais satisfatória para os usuários.

Este sistema de recomendação pode ser diretamente aplicado em plataformas de streaming para melhorar a retenção de usuários e a experiência personalizada, contribuindo para o aumento da satisfação do cliente e o sucesso do negócio. Além disso, sua arquitetura pode ser adaptada para outros contextos, como e-commerces e plataformas de aprendizado, expandindo seu alcance e utilidade.

Para o futuro, recomenda-se explorar a integração de técnicas híbridas, que possam combinar os pontos fortes das duas abordagens de filtragem apresentadas. Além disso, novas soluções que façam uso de aprendizado profundo têm potencial para melhorar ainda mais a precisão das recomendações, criando uma experiência mais única e personalizada para cada usuário.

REFERÊNCIAS

AGUIAR, Janderson Jason B.; ARAÚJO, Joseana M. F. R. de; COSTA, Evandro de B. Estudo de desempenho de algoritmos de filtragem colaborativa para sistemas de recomendação educacionais aplicando agrupamento prévio de usuários com traços de personalidade similares. **Anais do XXXI Simpósio Brasileiro de Informática na Educação (SBIE 2020)**. 2020. Disponível em: <https://journalofbigdata.springeropen.com/articles/10.1186/s40537-022-00592-5>. Acesso em: 13 jun. 2024.

ALURA. **Introdução a sistemas de recomendação com Python**. Disponível em: <https://www.alura.com.br/conteudo/introducao-a-sistemas-de-recomendacao-com-python>. Acesso em: 13 jun. 2024.

ANALYTICS INDIA MAG. **Cold-start problem in recommender systems and its mitigation techniques**. 2023. Disponível em: <https://analyticsindiamag.com/cold-start-problem-in-recommender-systems-and-its-mitigation-techniques>. Acesso em: 16 jun. 2024.

ARBELÁEZ-CAMPILLO, Diego Felipe; ESPINOZA, Jorge Jesús Villasmil; BAHAMÓN, Magda Julissa Rojas. Inteligencia artificial y condición humana: ¿entidades contrapuestas o Fuerzas complementarias? **Revista de Ciencias Sociales**, v. XXVII, n. 2, p. 502-513, 2021. Disponível em: <https://www.redalyc.org/journal/280/28066593034/>. Acesso em: 09 jun. 2024.

ASSIM – ASSOCIAÇÃO DE INTERPRETE E MÚSICOS. **Streaming**: o nome do jogo. Disponível em: <https://www.assim.org.br/c%C3%B3pia-streaming>. Acesso em: 07 jun. 2024.
BURROUGHS, Benjamin. The Netflix effect: teens, binge watching, and on-demand digital media trends. **Jeunesse: Young People, Texts, Cultures**, v. 7, n. 1, p. 119-138, 2014. Disponível em: https://www.researchgate.net/publication/270665559_The_Netflix_Effect_Teens_Binge_Watching_and_On-Demand_Digital_Media_Trends. Acesso em: 10 jun. 2024.

CAMPOS, Aline de; HOLLERWEGER, Leonéia; SANTOS, Gabriela; FARIAS, Adriano F.; BEHAR, Patricia A. Mapeamento de soluções tecnológicas em sistemas de recomendação educacionais em âmbito brasileiro. **Informática na Educação: teoria & prática**, Porto Alegre, v. 20, n. 3, p. 78-93, set./dez. 2017. Disponível em: <https://seer.ufrgs.br/index.php/InfEducTeoriaPratica/article/view/79624/47112>. Acesso em: 13 jun. 2024.

COLLI, Emanuel; SILVEIRA, Sidnei Renato. Sistema de recomendação de objetos de aprendizagem baseado em estilos cognitivos e na Taxonomia de Bloom. **Revista Educere Et Educare**, v. 18, n. 45, p. 47-67, 2023. Disponível em: <https://e-revista.unioeste.br/index.php/educereeteducare/article/download/30523/21819/120648>. Acesso em: 16 jun. 2024.

DHRUV, Verma; GULATI, Kshitij; SHAH, Rajiv Ratn. Addressing the Cold-Start problem in outfit recommendation using visual preference modelling. **Sixth International Conference on Multimedia Big Data (BigMM)**, p. 251-256, 2020. Disponível em: https://dhruv-verma.com/docs/Addressing_IEEE_BigMM_2020.pdf. Acesso em: 13 jun. 2024.
FAREED, Aamir; HASSAN, Saima; BELHAOUARI, Samir Brahim; HALIM, Zahid. A collaborative Filtering Recommendation Framework Utilizing Social Networks. **Machine Learning with Applications**, v. 14, p. 1-16, 2023. Disponível em: https://www.researchgate.net/publication/364626538_A_Collaborative_Filtering_Recommendation_Framework_Utilizing_Social_Networks. Acesso em: 10 jun. 2024.

GALLARDO-CAMACHO, Jorge; LAVÍN, Eva; FERNÁNDEZ-GARCÍA, Paula. Los programas de televisión deportivos y su relación con la audiencia social en Twitter en España. **Revista Latina de Comunicación Social**, n. 71, p. 272-286, 2016. Disponível em: <https://nuevaepoca.revistalatinacs.org/index.php/revista/article/view/810>. Acesso em: 07 jun. 2024.

GOMEZ-URIBE, Carlos A.; HUNT, Neil. The Netflix recommender system: algorithms, business value, and innovation. **ACM Transactions on Management Information Systems**, v. 6, n. 4, p. 1-19, 2015. Disponível em: <https://dl.acm.org/doi/pdf/10.1145/2843948>. Acesso em: 13 jun. 2024.

GOOGLE DEVELOPERS. **Collaborative filtering basics**. 2023. Disponível em: <https://developers.google.com/machine-learning/recommendation/collaborative/basics?hl=pt-br>. Acesso em: 13 jun. 2024.

GRANATYR, Jones. **Inteligência artificial: sistemas de recomendação em Python.** Disponível em: <https://www.udemy.com/course/inteligencia-artificial-sistemas-de-recomendacao-em-python/>. Acesso em: 5 nov. 2024.

GUARIZI, Débora Delfim; OLIVEIRA, Eliane Vendramini de. Estudo da Inteligência Artificial Aplicada na Área da Saúde. **Colloquium Exactarum**, Presidente Prudente, v. 6, n. Especial, p. 26-37, jul.-dez. 2014. Disponível em: <http://www.unoeste.br/site/enepe/2014/suplementos/area/Exactarum/Computa%C3%A7%C3%A3o/ESTUDO%20DA%20INTELIG%C3%8ANCIA%20ARTIFICIAL%20APLIACADA%20NA%20%C3%81REA%20DA%20SA%C3%9ADE.pdf>. Acesso em: 09 jun. 2024.

GUERRERO PÉREZ, Enrique. La fuga de los millennials de la televisión lineal. **Revista Latina de Comunicación Social**, v. 73, p. 1231-1246, 2018. Disponível em <https://nuevaepoca.revistalatinacs.org/index.php/revista/article/view/507>. Acesso em: 07 jun. 2024.

GUTIÉRREZ LOZANO, Juan Francisco; CUARTERO, Antonio. El auge de twitch: nuevas ofertas audiovisuales y cambios del consumo televisivo entre la audiencia juvenil. **Ámbitos. Revista Internacional de Comunicación**, n. 50, p. 159-175, 2020. Disponível em: <https://revistascientificas.us.es/index.php/Ambitos/article/view/12820>. Acesso em: 09 jun. 2024.

IFPI – INTERNATIONAL FEDERATION OF THE PHONOGRAPHIC INDUSTRY. **Music Consumer Insight Report 2018**. Londres: IFPI, 2018. Disponível em: <https://www.ifpi.org/our-industry/consumer-research/music-consumer-insight-report-2018/>. Acesso em: 07 jun. 2024.

JENKINS, Henry. **Cultura da conexão: criando valor e significado por meio da mídia propagável**. São Paulo: Aleph, 2014.

KARAKAYALI, Nedim; KOSTEM, Burc; GALIP, Idil. Recommendation Systems as technologies of the Self: algorithmic control and the formation of music taste. **Theory, Culture & Society**, v. 35, n. 2, p. 3-24, 2018. Disponível em: https://www.researchgate.net/publication/318893945_Recommendation_Systems_as_Technologies_of_the_Self_Algorithmic_Control_and_the_Formation_of_Music_Taste. Acesso em: 12 jun. 2024.

KISCHINHEVSKY, Marcelo; VICENTE, Eduardo; DE MARCHI, Leonardo de. Em busca da música infinita: os serviços de streaming e os conflitos de interesse no mercado de conteúdos digitais. **Revista Fronteiras**, v. 17, n. 3, p. 302-311, 2015. Disponível em: <https://revistas.unisinos.br/index.php/fronteiras/article/view/fem.2015.173.04/4990>. Acesso em: 06 jun. 2024.

LAMFO. **Sistemas de Recomendação usando Collaborative Filtering**. Disponível em: <https://lamfo-unb.github.io/2018/09/29/Sistemas-de-Recomenda%C3%A7%C3%A3o-usando-Collaborative-Filtering/>. Acesso em: 20 nov. 2024.

LAZY PROGRAMMER INC. **Recommender systems and deep learning in Python**. Disponível em: <https://www.udemy.com/course/recommender-systems/>. Acesso em: 5 nov. 2024.

LOBATO, Ramon. **The politics of digital distribution: exclusionary structures in online cinema.** New York-Estados Unidos da América: Routledge, 2016.

LUDERMIR, Teresa Bernarda. Inteligência artificial e aprendizado de máquina: estado atual e tendências. **Estudos Avançados**, v. 35, n. 101, p. 85-94, 2021. Disponível em: <https://www.scielo.br/j/ea/a/wXBdv8yHBV9xHz8qG5RCgZd/?format=pdf&lang=pt>. Acesso em: 10 jun. 2024.

MARCONI, Marina de Andrade; LAKATOS, Eva Maria. **Metodologia do trabalho científico: projetos de pesquisa/pesquisa bibliográfica/teses de doutorado, dissertações de mestrado, trabalhos de conclusão de curso.** 8. ed. São Paulo: Atlas, 2017.

MCKINSEY GLOBAL INSTITUTE. **Artificial intelligence: the next digital frontier?** 2017. Disponível em: https://www.mckinsey.com/~/_/media/mckinsey/industries/advanced%20electronics/our%20insights/how%20artificial%20intelligence%20can%20deliver%20real%20value%20to%20companies/mgi-artificial-intelligence-discussion-paper.ashx. Acesso em: 09 jun. 2024.

MONTARDO, Sandra Portella; VALIATI, Vanessa Amália Dalpizol. Streaming de conteúdo, streaming de si? Elementos para análise do consumo personalizado em plataformas de streaming. **Revista FAMECOS**, Porto Alegre, v. 28, p. 1-14, jan.-dez. 2021. Disponível em: <https://revistaseletronicas.pucrs.br/ojs/index.php/revistafamecos/article/view/35310/26907>. Acesso em: 09 jun. 2024.

MUNGIOLI, Maria Cristina Palma; IKEDA, Flavia Suzue de Mequista; PENNER, Tomaz Affonso. Estratégias de streaming de séries brasileiras na Plataforma Globoplay no período de 2016 a 2018. **Revista GEMInIS**, v. 9, n. 3, p. 52-63, 2018. Disponível em: <https://www.revistageminis.ufscar.br/index.php/geminis/article/view/413/318>. Acesso em: 05 jun. 2024.

NATH, Sruthy. Overcoming Data Sparsity with Collaborative Filtering. Medium, 14 set. 2023. Disponível em: <https://medium.com/@sruthy.sn91/overcoming-data-sparsity-with-collaborative-filtering-e9a3519376f5>. Acesso em: 28 jun. 2024.

NAVARRO, S. N. Obras generadas por algoritmos. en torno a su posible protección jurídica. **Revista de Derecho Civil**, v. 5, n. 2, p. 273-291, 2018. Disponível em: <https://dialnet.unirioja.es/servlet/articulo?codigo=6485166>. Acesso em: 09 jun. 2024.

NEIRA, Elena; CLARES-GAVILÁN, Judith; SÁNCHEZ-NAVARRO, Jordi. New audience dimensions in streaming platforms: the second life of Money heist on Netflix as a case study. **Profesional de la información**, v. 30, n. 1, e300113, p. 1-17, 2021. Disponível em: <https://revista.profesionaldelainformacion.com/index.php/EPI/article/view/80582/62914>. Acesso em: 08 jun. 2024.

NETFLIX. **Como funciona o sistema de recomendações da Netflix.** Netflix - Central de Ajuda, 2019. Disponível em: <https://help.netflix.com/pt/node/100639>. Acesso em: 13 jun. 2024.

OLIVEIRA, Arthur Freitas; PINHEIRO, Priscilla Mendonça; DUTRA, Júlio Afonso Alves. Serviços de streaming: histórico, consumo e perspectivas. **RECIMA21 - Revista Científica Multidisciplinar** – Ciências Exatas e da Terra, Sociais, da Saúde, Humanas e Engenharia/Tecnologia, v. 4, n. 11, p. 1-14, 2023. Disponível em: <https://recima21.com.br/index.php/recima21/article/view/4314/3088>. Acesso em: 07 jun. 2024.

PASQUÍN, Manuel Álvarez de la Gala. De la planificación en TV a la planificación audiovisual y social: desafíos para la industria ante un cambio de paradigma en la medición de la eficacia publicitaria. 2017, 300f. Tese (Doutorado em Comunicação) – Universidade Complutense de Madrid, Madrid, Espanha, 2017. Disponível em: <https://docta.ucm.es/entities/publication/3334f9d4-0e69-4d20-b943-d598c1f3fc7e>. Acesso em: 10 jun. 2024.

PINTO, Adilson Luiz; DIAS, Thiago Magela Rodrigues; SILVA, Vivian Santos; GOMES, Josir Cardoso; CARVALHO SEGUNDO, Washington Luis R. de. (2021). BrCRIS como um sistema de recomendação científico-tecnológica. **XXI Encontro Nacional de Pesquisa em Ciência da Informação – ENANCIB 2021**. Rio de Janeiro, 25-29 de outubro de 2021. Disponível em: https://www.researchgate.net/publication/356640074_BrCRIS_COMO_UM_SISTEMA_DE_RECOMENDACAO_CIENTIFICO-TECNOLOGICA/link/61a61d67b4bbff76e2778aaa/download?_tp=eyJjb250ZXh0Ijp7ImZpcnN0UGFnZSI6InB1YmxpY2F0aW9uIiwicGFnZSI6InB1YmxpY2F0aW9uIn19. Acesso em: 08 jun. 2024.

RAMOS, Durval; OLIVEIRA, Jones. **Como a Netflix ganha dinheiro?** Canaltech. 2022. Disponível em: <https://canaltech.com.br/entretenimento/como-a-netflix-ganha-dinheiro-220830/>. Acesso em: 04 jun. 2024.

ROSSONI, Luciano. A inteligência artificial e eu: escrevendo o editorial juntamente com o ChatGPT. **Revista Eletrônica de Ciência Administrativa**, v. 21, n. 3, p. 399-405, set.-dez. 2022. Disponível em: <https://www.periodicosibepes.org.br/index.php/recadm/article/view/3761>. Acesso em: 09 jun. 2024.

SANTODIGITAL. Inteligência Artificial: O Que é e Quais Seus Benefícios? Disponível em: <https://santodigital.com.br/inteligencia-artificial-o-que-e-e-quais-seus-beneficios/>. Publicado em: 12 ago. 2022. Acesso em: 09 jun. 2024.

SMITH, Michael D.; TELANG, Rahul. **Streaming, sharing, stealing: big data and the future of entertainment**. Cambridge-Inglaterra: MIT Press, 2016.

SOLITTO, André. **A força do streaming**. 2018. Disponível em: <https://istoe.com.br/a-forca-do-streaming/>. Acesso em: 04 jun. 2024.

SYBHE, A. O desafio do Cold Start em IA Generativa e Sistemas de Recomendação. **LinkedIn**. 2023. Disponível em: <https://www.linkedin.com/pulse/o-desafio-do-cold-start-em-ia-abiage-sybhe/>. Acesso em: 16 jun. 2024

THINGSOLVER. **How to solve the cold start problem in recommender systems.** Disponível em <https://medium.com/@markmilankovich/the-cold-start-problem-for-recommender-systems-89a76505a7>. Acesso em: 16 jun. 2024.

TURING. **How does collaborative filtering work in recommender systems?** 2023. Disponível em: <https://www.turing.com/kb/collaborative-filtering-in-recommender-system>. Acesso em: 13 jun. 2024.

YU, Yonghong; WANG, Can; GAO, Yang. **Attributes Coupling based Item Enhanced Matrix Factorization Technique for Recommender Systems.** arXiv preprint arXiv:1405.0770, 2014. Disponível em: <https://arxiv.org/abs/1405.0770>. Acesso em: 20 nov. 2024.

ZHANG, Shuai; YAO, Lina; SUN, Aixin; TAY, Yi. **Deep Learning Based Recommender System: A Survey and New Perspectives.** ACM Computing Surveys, v. 52, n. 1, p. 1-38, 2019. Disponível em: <https://arxiv.org/abs/1707.07435>. Acesso em: 20 nov. 2024.